





Типичный Enterprise

В организации		
Приложений	500-5000	
CPU-ядер	1-5 млн	
Хранение	10-100 PB	
Дата-центров	5-20	
Стоимость оборудования	1-5 млрд. USD	
Количество поддержки	300-1500 инженеров поддержки и	
	технических контактов в приложениях	
Стоимость функционирования	150-500 млн. USD / год	

Типичный Enterprise - история

- 50–100 лет истории бизнеса и 40+ лет ИТ
- Использование всех технологий когда-либо существовавших
- IBM 360, мейнфреймы, AS/400, AIX, HPUX, Sparc/Solaris...
- Kobol, C/C++ 20-летней давности...

Типичный Enterprise – история

- Ключевой фактор инфраструктуры надежность
- Типичный дизайн пара дата-центров:
 - В основном ДЦ active/passive HA
 - Во вспомогательном ДЦ DR, тестовые и разработческие среды
 - Многократное дублирование сетевых устройств

Типичный Enterprise – история

- Ключевой фактор разработки быстрая реализация бизнес-задач
- И даже разработка отдельных платформ для конкретных трейдеров/групп или продуктов

• Почему — только новые продукты приносят деньги. Как только продукт появляется у конкурентов, цена падает до порога прибыльности

- 40 лет гонки за бизнес-задачами породили колоссальную сложность управления софтом и инфраструктурой
- Оптимизацией с точки зрения стоимости владения никто не занимался
- Оптимизацией с точки зрения стоимости инфраструктуры никто не занимался

Сложность достигла такого уровня, что стоимость владения начала существенно влиять на стоимость ведения бизнеса, даже с учетом достаточной прибыльности инвестиционных банков

Колоссальная инертность — «40 лет всё было хорошо, почему проблемы возникли сейчас?»

· Средняя загрузка CPU 5-15%

• Средняя загрузка сети 1-5-10%

· Двадцать дата-центров полностью забиты оборудованием

Как следствие:

Очень длинное время доставки оборудования	Очень много старого оборудования
Сложная 3-4 уровневая топология сети	Проблемы с расширяемостью
Плохая скорость сети	Плохая скорость систем хранения

Только когда проблемы ИТ стали серьезно мешать бизнесу, бизнес принял решение о трансформации ИТ и стал интересоваться, что и как можно улучшить

Вот так могу

Oak Ridge Supercomputer Center (суперкомпьютер Summit)		
Приложений	500-10000	<100
CPU-ядер	1-5 млн	2.4 млн* (вместе с GPU)
Хранение	10-100 PB	250 PB
Дата-центров	5-20	600m2
Стоимость оборудования	1-5 млрд. USD	0.25 млрд. USD
Количество поддержки	300-1500 инженеров	30 инженеров
Run cost	150-500M USD / год	50M USD/ год

For internal use only

Oak Ridge Supercomputer Center (суперкомпьютер Summit)

30 инженеров – никакой сложности поддержки

Нет диверсификации оборудования

Малая полная стоимость оборудования

Малое количество единиц оборудования

Нет проблем с расширением

Гипер-скоростная и простая сеть

Гипер-скоростная система хранения

Что дает НРС-оборудование – сеть



Mellanox CS8500

800 портов по 200Гб/сек 320 Тб/сек полная скорость переключений 1-2х уровневая сеть 130нс латентность

Что дает НРС-оборудование – хранение



Supermicro NVMe-стойка

672М операций в секунду 840GB/s пропускная способность 10.7 PB емкость (8TB NVMe SSD)

Что дает НРС-оборудование – сервера



Atos BullSequana XH2000

32 лезвия

3 сервера на лезвие

В стойке:

12288 ядер (Ерус 64 ядра)

196 ТБ памяти (128GB модуль)

19.2Тб/sec пропускной способности сети

Как использовать HPC-оборудование в Enterprise/Highload?

Лучше писать Software ©

Как лучше писать Software?

Отрицание Гнев Торг Депрессия Принятие

Микросервисы в НРС-стиле

Площадь ячейки равна объему работы

Микросервисы

Микросервисы в НРС-стиле

Площадь ячейки равна объему работы

Автоматическое масштабирование	Разделение процессов сохранения данных и обработки	
Асинхронность & пакетная обработка	Низко-латентные высоко- скоростные протоколы (UDP)	
Фреймворки контроля бизнес/технических показателей и среды		
Полный мониторинг платформ		

Автоматическое масштабирование

Масштабирование – увеличение/уменьшение количества реплик/инстансов в зависимости от:

- 1. Простой вариант в зависимости от загрузки CPU/памяти/сети
- 2. Сложный в зависимости от бизнес-процессов

Разделение процессов сохранения данных и обработки

• Быстрые операции обработки данных в памяти не должны упираться в конце в ожидание записи в базу данных или другое персистентное хранилище

Варианты:

- 1. Запись результатов в распределенный кэш
- 2. Оправка сообщением

Асинхронность & пакетная обработка

Количество операций в распределенных системах ограничено задержками.

При задержках 1мс, возможно только 1000 операций в секунду

Правило:

Одна операция должна работать с десятками и сотнями объектов, а не с одним объектом – асинхронность с клиентом + пакетная обработка

Низко-латентные высоко-скоростные протоколы (UDP)

Протоколы с подтверждением в сети IB не нужны

Приоритет — нано-секундная латентность

Варианты библиотек UDP-протокола:

- 1. smUDP (Одноклассники)
- 2. Aeron (Martin Thompson)

Фреймворки контроля бизнес/технических показателей и среды

Борьба с перегрузками и ООМ

- 1. Ограничение количества запросов
- 2. Ограничение по использованию памяти/цпу
- 3. Проверки связности с другими сервисами (trottling)

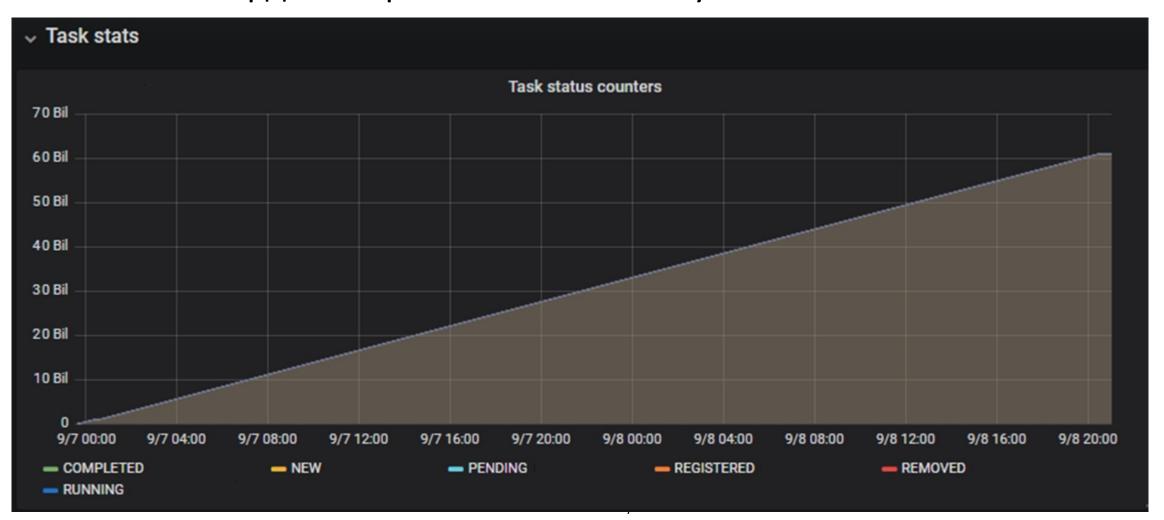
Полный мониторинг платформ

- Мониторинг индивидуальных инстансов
- · Мониторинг внутренних параметров (GC, cpu usage/ram usage/thread usage/ времена get/put на map/queue/list/set)
- · Мониторинг бизнес-показателей (операций в секунду/продолжительность операций)

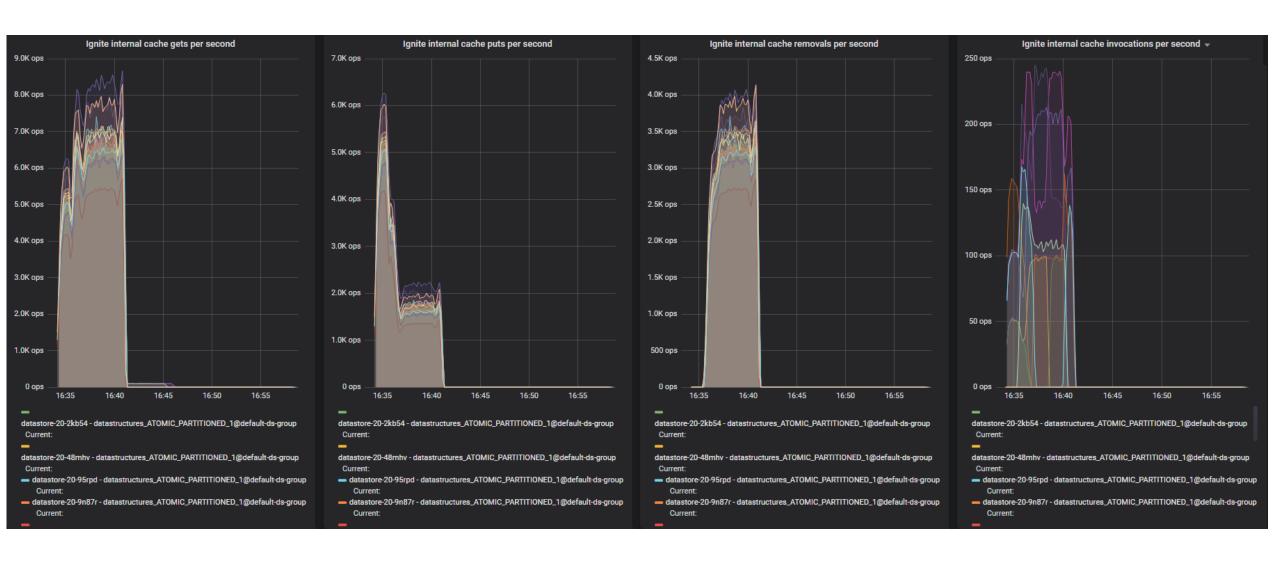
- · Забудьте о логах только метрики в Prometheus
- Логи только для неструктурированных ошибок

Что же получим в результате?

60 миллиардов запросов за 44 часа – Гугл на обычном железе



Мониторинг низкоуровневых операций



Мониторинг асинхронности (thread pool)

Здесь будет слайд с 85К распределенных операций в секунды, как безопасники согласуют

Q&A